

Statistique élémentaire avec **R**

Partie 1 : Probabilités, Statistiques Descriptives, Estimation

Julien JACQUES

Université Lumière Lyon 2

Plan

Notions de probabilités

Statistiques descriptives

Estimation

Plan

Notions de probabilités

Généralités

Variables aléatoires discrètes et lois associées

Variables aléatoires continues et lois associées

Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

Description d'une variable quantitative

Description d'une variable qualitative

Description conjointe de plusieurs variables

Estimation

Estimation ponctuelle

Intervalles de confiance

Probabilités

Le formalisme

- \mathcal{E} : expérience aléatoire
- Ω : ensemble des résultats possibles de \mathcal{E} (*univers*)
- $A \in \Omega$: événement

Opérations sur les événements

- union $A \cup B$: A ou B (ou les 2) est réalisé
- intersection $A \cap B$: A et B sont réalisés en même temps
si $A \cap B = \emptyset$, A et B sont incompatibles
- complémentaire \bar{A} : A n'est pas réalisé

Propriété : $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$

Probabilités

Définition d'une probabilité

Probabilité :

$$\begin{aligned} P : \Omega &\rightarrow [0, 1] \\ A &\rightarrow P(A) \end{aligned}$$

où $P(A) \simeq$ évaluation des chances de réalisation de A lors d'une expérience aléatoire.

- $0 \leq P(A) \leq 1$ pour tout $A \in \Omega$
- $P(\Omega) = 1$
- $A, B \in \Omega$ tels que $A \cap B = \emptyset$: $P(A \cup B) = P(A) + P(B)$
on dit que A et B sont *incompatibles*

Probabilités

Propriétés

- $P(\emptyset) = 0$
- $P(\bar{A}) = 1 - P(A)$
- si $A \subset B : P(A) \leq P(B)$
- si $A \cap B \neq \emptyset : P(A \cup B) = P(A) + P(B) - P(A \cap B)$

Quelques définitions

- probabilité *conditionnelle* que A soit réalisé sachant que B l'est

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

- *indépendance* : A et B sont indépendants si $P(A|B) = P(A)$
 $\Rightarrow P(A \cap B) = P(A)P(B)$

Probabilités

Formule des probabilités totales

Soit A_1, A_2, \dots, A_n un système complets d'événements, i.e. :

- $A_i \cap A_j = \emptyset$ pour tout $i \neq j$,
- $A_1 \cup A_2 \cup \dots \cup A_n = \Omega$.

Alors pour tout B :

$$P(B) = \sum_{i=1}^n P(B \cap A_i)$$

Probabilités

Formules de Bayes

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

et si A_1, A_2, \dots, A_n est un système complets d'événements

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_{i=1}^n P(B \cap A_i)} = \frac{P(B|A_i)P(A_i)}{\sum_{i=1}^n P(B|A_i)P(A_i)}$$

Probabilités

Calculer une probabilité

Lorsqu'on sait dénombrer les événements :

$$P(A) = \frac{\text{nombre de cas favorables}}{\text{nombre de cas possibles}}$$

valide lorsque tous les cas sont équiprobables

Dénombrément

- $n! = 1 \times 2 \times \dots \times n$ (nombre de permutations de n objets) : nombre de façons de ranger n objets
- C_n^k (combinaisons de k parmi n) : nombre de choix possibles de k objets parmi n

$$C_n^k = \frac{n!}{k!(n-k)!}$$

Variables aléatoires

Variable aléatoire

$$X : \Omega \rightarrow E$$

- Ω : ensemble d'événements possibles ou d'individus
- E : valeurs possibles de X

Les différents types de variables aléatoires

- quantitative
 - discrète : nombre de clients $E = \{1, 2, 3, \dots\}$
 - continue : taille, poids $E = \mathbb{R}$
- qualitative
 - nominale : couleur des yeux $E = \{bleu, vert, noir, \dots\}$
 - ordinale : mention au BAC $E = \{P, AB, B, TB\dots\}$

Plan

Notions de probabilités

Généralités

Variables aléatoires discrètes et lois associées

Variables aléatoires continues et lois associées

Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

Description d'une variable quantitative

Description d'une variable qualitative

Description conjointe de plusieurs variables

Estimation

Estimation ponctuelle

Intervalles de confiance

Variables aléatoires quantitatives discrètes

$$X : \Omega \rightarrow E \quad \text{avec } E = \{x_1, \dots, x_k\}$$

Distribution (loi) de X

$$X \sim \begin{pmatrix} x_1 & \dots & x_i & \dots & x_k \\ p_1 & \dots & p_i & \dots & p_k \end{pmatrix}$$

où $p_i = P(X = x_i)$ $(\sum_{i=1}^k p_i = 1)$


On supposera (par convention)

$$x_1 \leq \dots \leq x_i \leq \dots \leq x_k$$

Caractéristiques d'une variable discrète

Fonction de répartition

$$F_X(x) = P(X \leq x) = \begin{cases} 0 & \text{si } x < x_1 \\ p_1 & \text{si } x_1 \leq x < x_2 \\ p_1 + p_2 & \text{si } x_2 \leq x < x_3 \\ \vdots & \\ 1 & \text{si } x \geq x_k \end{cases}$$



Caractéristiques d'une variable discrète

Espérance

$$E[X] = \sum_{i=1}^k p_i x_i$$

valeur théorique moyenne à laquelle on peut s'attendre pour X

Propriétés

- on note $E[X] = \mu$
- si X et Y sont deux variables aléatoires, et a une constante :
 $E[aX + Y + b] = aE[X] + E[Y] + b$
- $E[XY] \neq E[X]E[Y]$ sauf si X et Y sont indépendantes

Caractéristiques d'une variable discrète

Variance

$$V(X) = E[(X - E[X])^2] = \sum_{i=1}^k p_i (x_i - \mu)^2 = \sum_{i=1}^k p_i x_i^2 - \mu^2$$

moyenne des carrés des écarts de X à sa moyenne μ

Propriétés :

- on note $V(X) = \sigma^2$
- on appelle écart-type : $\sigma = \sqrt{V(X)}$
- $V(a + X) = V(X)$ et $V(aX) = a^2 V(X)$
- $V(X + Y) \neq V(X) + V(Y)$ sauf si X et Y sont indépendantes

Exemples de lois discrètes

Soit $A \in \Omega$ tel que $P(A) = p$.

Bernoulli $\mathcal{B}(p)$

On réalise une expérience aléatoire \mathcal{E} et on définit

$X = 1$ si A est réalisé, 0 sinon

$$X \sim \begin{pmatrix} 0 & 1 \\ 1-p & p \end{pmatrix}$$

- $E[X] = p$
- $V(X) = p(1-p)$

Exemples de lois discrètes

Soit $A \in \Omega$ tel que $P(A) = p$.

binomiale $\mathcal{B}(n, p)$

On répète n fois de façon indépendante et dans les mêmes conditions l'expérience aléatoire \mathcal{E}


X = nombre de fois où A est réalisé.

$$X \sim \begin{pmatrix} 0 & 1 & \dots & n \\ p_0 & p_1 \dots & p_n \end{pmatrix}$$

avec $p_j = P(X = j) = C_n^j p^j (1-p)^{n-j}$

Propriétés:

- $E[X] = np$
- $V(X) = np(1-p)$



Exemples de lois discrètes

Poisson $\mathcal{P}(\lambda)$

On compte un nombre d'événements A indépendants se produisant dans un intervalle de temps fixé


X = nombre d'événements A réalisés.

$X \in \mathbb{N}$

avec $P(X = j) = e^{-\lambda} \frac{\lambda^j}{j!}$

Propriétés:

- $E[X] = \lambda$
- $V(X) = \lambda$



Exercice sur la loi binomiale

Lancer de dé

- je lance un dé non truqué. Quelle est la probabilité d'obtenir 6 ?
- je lance deux dés non truqués. Quelle est la probabilité d'obtenir au moins un 6 ?
- je lance dix dés non truqués. Quelle est la probabilité d'obtenir au moins un 6 ?

Plan

Notions de probabilités

Généralités

Variables aléatoires discrètes et lois associées

Variables aléatoires continues et lois associées

Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

Description d'une variable quantitative

Description d'une variable qualitative

Description conjointe de plusieurs variables

Estimation

Estimation ponctuelle

Intervalles de confiance

Variables aléatoires quantitatives continues

$$X : \Omega \rightarrow E \quad \text{avec } E \subseteq \mathbb{R}$$


$P(X = x) = 0$ pour tout $x \in E$ car E non dénombrable.

On s'intéresse plutôt à $P(X \in [a, b])$.

Distribution et fonction de densité

X est caractérisée par sa fonction de densité $f_X : \mathbb{R} \rightarrow \mathbb{R}^+$

$$P(X \in [a, b]) = P(X \in]a, b]) = \int_a^b f_X(x) dx$$



Variables aléatoires quantitatives continues


$$X : \Omega \rightarrow E \quad \text{avec } E \subseteq \mathbb{R}$$

Fonction de répartition

X peut également être caractérisée par sa fonction de répartition

$$F_X : \mathbb{R} \rightarrow [0, 1]$$

$$P(X \leq a) = P(X < a) = \int_{-\infty}^a f_X(x) dx$$



Caractéristiques d'une variable continue

Espérance

$$E[X] = \int_{-\infty}^{+\infty} x f_X(x) dx = \mu$$

valeur théorique moyenne à laquelle on peut s'attendre pour X

De plus, pour toute fonction h : $E[h(X)] = \int_{-\infty}^{+\infty} h(x) f_X(x) dx$

Variance

$$V(X) = \int_{-\infty}^{+\infty} (x - \mu)^2 f_X(x) dx = \int_{-\infty}^{+\infty} x^2 f_X(x) dx - \mu^2$$

moyenne des carrés des écarts de X à sa moyenne μ

Caractéristiques d'une variable continue

Quantile

On appelle quantile d'ordre α , le nombre q_α tel que :

$$P(X \leq q_\alpha) = \alpha \quad \text{et} \quad P(X > q_\alpha) = 1 - \alpha$$

- Pour une loi discrète, il peut exister une infinité de valeur respectant ces deux conditions.
On prendra par convention la plus petite.
- Pour une loi continue, les deux égalités sont vérifiées.

Médiane


On appelle médiane le quantile d'ordre $\alpha = 50\%$.

Exemple de loi continue : la loi normale

normale $\mathcal{N}(\mu, \sigma^2)$

Densité de la loi normale (gaussienne) de paramètres μ et σ^2 :

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{x - \mu}{\sigma}\right)^2\right)$$



Propriétés :

- $E[X] = \mu$
- $V(X) = \sigma^2$
- symétrie :


$$P(X < \mu - a) = P(X > \mu + a)$$

Exemple de loi continue : la loi normale

Cas particulier normale centrée réduite $\mathcal{N}(0, 1)$

Il existe des tables permettant de lire $P(X < u)$ pour $u > 0$.

La fonction pnorm de R donne également $P(X < u)$ pour u donné.



Exemples :


$$P(X < 1.6449) = 95\%$$

$$P(X < 1.96) = 97.5\%$$

Exemple de loi continue : la loi normale

Cas particulier normale centrée réduite $\mathcal{N}(0, 1)$

La fonction q_{norm} donne la valeur du quantile d'ordre α , souvent notée u_α pour la loi normale centrée réduite.



Exemple de loi continue : la loi normale

Utilité de la $\mathcal{N}(0, 1)$

Si $X \sim \mathcal{N}(\mu, \sigma^2)$

$$Z = \frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1)$$

d'où

$$P(X < a) = P\left(\frac{X - \mu}{\sigma} < \frac{a - \mu}{\sigma}\right) = P\left(Z < \frac{a - \mu}{\sigma}\right)$$

et on utilise la table.

Exercice sur la loi normale

Calcul de probabilité normale

Soit $X \sim \mathcal{N}(2, 4)$. Calculer, à l'aide des tables statistiques

- $P(X = 2)$
- $P(X > 2)$ et $P(X \geq 2)$
- $P(0 < X < 4)$ et $P(-2 < X < 6)$
- Soit $Y \sim \mathcal{N}(0, 1)$. Quel lien y-a-t'il entre $P(X > 4)$ et $P(Y > 1)$?

Exemple de loi continue : la loi exponentielle

exponentielle $\mathcal{E}(\lambda)$


Modélise des durées (de vie en fiabilité, pour matériel sans usure ni fatigue)

Densité de la loi exponentielle de paramètre λ :

$$f_X(x) = \lambda e^{-\lambda x} \text{ si } x > 0$$

Propriétés:

- $E[X] = 1/\lambda$
- $V(X) = 1/\lambda^2$



Exemple de loi continue : la loi de Weibull

Weibull $\mathcal{W}(\alpha, \beta)$

Modélise des durées de vie en fiabilité

Densité de la loi de Weibull de paramètre α, β :

$$f_X(x) = \frac{\alpha}{\beta} \left(\frac{x}{\beta}\right)^{\alpha-1} \lambda e^{-(x/\beta)^\alpha} \text{ si } x > 0$$

Propriétés:


• α lié au vieillissement:

$\alpha = 1 \Rightarrow$ loi $\mathcal{E}(1/\beta)$,

$\alpha > 1 \Rightarrow$ matériel qui se fatigue

• β lié à la durée de vie médiane:

$\beta = \text{mediane}/((\ln 2)^{1/\alpha})$



Exemple de loi continue : la loi de Gumbel

Gumbel standard \mathcal{G}


Modélise des valeurs extrêmes (crues/magnitudes maximales annuelles...)

Densité :

$$f_X(x) = e^{-x-e^{-x}} \text{ si } x > 0$$

Fonction de répartition :

$$F_X(x) = p(X < x) = e^{-e^{-x}} \text{ si } x > 0$$



Plan

Notions de probabilités

Généralités

Variables aléatoires discrètes et lois associées

Variables aléatoires continues et lois associées

Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

Description d'une variable quantitative

Description d'une variable qualitative

Description conjointe de plusieurs variables

Estimation

Estimation ponctuelle

Intervalles de confiance

Liaison entre deux variables aléatoires quantitatives

Covariance

On définit la **covariance** entre deux variables aléatoires X et Y par

$$\text{Cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = E[XY] - \mu_X\mu_Y.$$

Interprétation :

Exprime la présence d'une relation du type $Y = aX + b$

- $\text{Cov}(X, Y) > 0$: les variables varient dans le même sens par rapport à leur moyenne,
- $\text{Cov}(X, Y) < 0$: les variables varient en sens inverse,
- $\text{Cov}(X, Y) = 0$: les variables ne sont pas corrélées linéairement (Attention : cela n'implique pas l'indépendance (sauf si les variables sont normales))

Remarque : $\text{Cov}(X, X) = V(X)$

Liaison entre deux variables aléatoires quantitatives

Corrélation

Comme la covariance n'est pas bornée, on définit la **corrélation** entre deux variables aléatoires X et Y par

$$\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}.$$

Propriété : $\rho_{X,Y} \in [-1, 1]$

Liaison entre deux variables aléatoires quantitatives

Indépendance

Deux variables aléatoires X et Y sont **indépendantes** si

$$P(\{X \in A\} \cap \{Y \in B\}) = P(\{X \in A\})P(\{Y \in B\}).$$

Propriétés :

- si X et Y sont à densité,
 X et Y indépendantes $\Rightarrow f_{X,Y}(x,y) = f_X(x)f_Y(y)$
- X et Y indépendantes $\Rightarrow Cov(X, Y) = 0 = \rho_{X,Y}$
(Attention \nLeftarrow)
- X et Y indépendantes \Rightarrow
 $f_{X+Y}(z) = f_X(x) \otimes f_Y(y) = \int_{\mathbb{R}} f_X(u)f_Y(z-u)du$

Liaison entre deux variables aléatoires quantitatives

Calcul d'inégalité aléatoire

Si X et Y sont indépendantes

$$\begin{aligned}P(X > Y) &= \int_{-\infty}^{\infty} \int_{-\infty}^x f_Y(y) f_X(x) dx dy \\ &= \int_{-\infty}^{\infty} \left(\int_{-\infty}^x f_Y(y) dy \right) f_X(x) dx\end{aligned}$$

Exemple d'application :

- X : résistance d'un matériau
- Y : force appliquée sur le matériau
- $P(X > Y)$: probabilité que le matériau résiste

Plan

Notions de probabilités

Statistiques descriptives

Estimation

Notion d'échantillon

Soit X la variable aléatoire d'intérêt.

Échantillon

On appelle échantillon toute suite X_1, \dots, X_n de variables aléatoires **indépendantes** et de **même loi** que la variable aléatoire X d'intérêt.

Exemple :

X : taille des individus de la population française

X_1, \dots, X_n : taille de n individus choisis au hasard dans la population française.

On notera x_1, \dots, x_n l'observation de l'échantillon aléatoire X_1, \dots, X_n .

Plan

Notions de probabilités

- Généralités

- Variables aléatoires discrètes et lois associées

- Variables aléatoires continues et lois associées

- Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

- Description d'une variable quantitative**

- Description d'une variable qualitative

- Description conjointe de plusieurs variables

Estimation

- Estimation ponctuelle

- Intervalles de confiance

Résumés numériques d'une variable quantitative

Tendance centrale

- **Moyenne** : $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$
- **Médiane** : valeur M qui partage l'échantillon ordonné en 2

$$M = X_{\frac{n+1}{2}} \text{ si } n \text{ impair, et } M = \frac{X_{\frac{n}{2}} + X_{\frac{n}{2}+1}}{2}$$

en supposant que l'échantillon X_1, \dots, X_n est classé par ordre croissant

- **Mode** : valeur la plus observée (*pour variables discrètes*)

Rq : \bar{X} et M sont des variables aléatoires, leurs observations sur un échantillon sont notées $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ et m .

Résumés numériques d'une variable quantitative

Dispersion

- **Variance** (empirique) : $V^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$
- **Étendue** : $X_{max} - X_{min}$
- **Intervalle inter-quartile** : $[Q_1, Q_3]$
où le premier quartile Q_1 est la valeur telle qu'1/4 des observations lui soient inférieures et 3/4 supérieures (et l'inverse pour le troisième quartile Q_3)

Résumés numériques d'une variable quantitative

Forme


- **skewness** : coefficient d'asymétrie $\gamma_1 = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^3}{(\sqrt{n/(n-1)}V)^3}$
- **kurtosis** : coefficient aplatissement $\gamma_2 = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^4}{(n/(n-1))^2 V^4}$

Propriétés :

- $X \sim \mathcal{N} \Rightarrow \gamma_1 = 0$ et $\gamma_2 = 3$ (0 pour Excel)
- $\gamma_1 > 0$: distribution décalée vers la gauche
- $\gamma_2 > 3$: distribution plus aplatie qu'une gaussienne

Représentation graphique d'une variable quantitative


Boîte à moustaches



- trait centré au milieu de la boîte : médiane
- la boîte est formée par les 1er quartile q_1 et 3ème quartile q_3
- les moustaches sont définies par les valeurs observées les plus extrêmes dans l'intervalle $[q_1 - 1.5(q_3 - q_1), q_3 + 1.5(q_3 - q_1)]$
- ○ : valeurs extrêmes hors des moustaches

Représentation graphique d'une variable quantitative

Histogramme : surface de chaque barre proportionnelle à l'effectif de la classe d'observations correspondante




Rq : si la variable est quantitative discrète, les “barres” sont remplacées par des “bâtons”

Représentation graphique d'une variable quantitative

Fonction de répartition empirique :

$$F_n(x) = \frac{N_x}{n}$$

où $N_x = \#\{X_i : X_i \leq x, 1 \leq i \leq n\}$ est le nombre de données inférieures ou égales à X .



Plan

Notions de probabilités

- Généralités

- Variables aléatoires discrètes et lois associées

- Variables aléatoires continues et lois associées

- Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

- Description d'une variable quantitative

- Description d'une variable qualitative**

- Description conjointe de plusieurs variables

Estimation

- Estimation ponctuelle

- Intervalles de confiance



Résumé numérique d'une variable qualitative

Si X est une variable aléatoire qualitative prenant les modalités $\{m_1, \dots, m_p\}$ on s'intéresse à

- $N_j = \#\{X_i : X_i = m_j, 1 \leq i \leq n\}$: le nombre d'occurrences (effectif) de la modalité m_j dans l'échantillon
- $F_j = \frac{N_j}{n}$: la **fréquence** de la modalité m_j dans l'échantillon

Représentation graphique d'une variable qualitative

Diagramme en camembert (*pie-chart*, gauche) et en barres (droite)



Plan

Notions de probabilités

- Généralités

- Variables aléatoires discrètes et lois associées

- Variables aléatoires continues et lois associées

- Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

- Description d'une variable quantitative

- Description d'une variable qualitative

- Description conjointe de plusieurs variables**

Estimation

- Estimation ponctuelle


- Intervalles de confiance

Décrire la liaison entre deux variables quantitatives

Numérique : le **coefficient de corrélation linéaire**

$$\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}.$$

Graphique : le **nuage de points** :




Décrire la liaison entre Y quantitative et X qualitative

Numérique : le **rapport de corrélation** :

$$R_{Y|X} = \sqrt{V_X^2 / V^2}$$

où $V_X^2 = \frac{1}{n} \sum_{j=1}^R N_j (\bar{Y}_j - \bar{Y})^2$ exprime la part de variabilité due à X (\bar{Y}_j étant la moyenne des Y observés lorsque $X = j$ ème modalité)

Graphique : le **boxplot** :



Décrire la liaison entre deux variables qualitatives

X : modalités m_1, \dots, m_R

Y : modalités o_1, \dots, o_C

	o_1	\dots	o_c	\dots	o_C	sommes
m_1	N_{11}	\dots	N_{1c}	\dots	N_{1C}	$N_{1\cdot}$
\vdots	\vdots		\vdots		\vdots	\vdots
m_r	N_{r1}	\dots	N_{rc}	\dots	N_{rC}	$N_{r\cdot}$
\vdots	\vdots		\vdots		\vdots	\vdots
m_R	N_{R1}	\dots	N_{Rc}	\dots	N_{RC}	$N_{R\cdot}$
sommes	$N_{\cdot 1}$	\dots	$N_{\cdot c}$	\dots	$N_{\cdot C}$	n

Table : Table de contingence

Décrire la liaison entre deux variables qualitatives

Mesure de liaison

- le χ^2 (non borné):

$$\chi^2 = \sum_{r=1}^R \sum_{c=1}^C \frac{(N_{rc} - \frac{N_r \cdot N_c}{n})^2}{\frac{N_r \cdot N_c}{n}} = n \left[\sum_{r=1}^R \sum_{c=1}^C \frac{N_{rc}^2}{N_r \cdot N_c} - 1 \right]$$

- le $\phi^2 = \frac{\chi^2}{n}$ (dépend encore de C et de R)
- le C de Cramer ($\in [0, 1]$) $C = \sqrt{\frac{\phi^2}{\inf(R,C)-1}}$
- le T de Tschuprow ($\in [0, 1]$) $T = \sqrt{\frac{\phi^2}{(R-1)(C-1)}}$

Plan

Notions de probabilités

Statistiques descriptives

Estimation

Notion d'estimation

X une variable aléatoire

θ un paramètre caractérisant X dans une population donnée.

Ex :

- θ : la moyenne de X , $E[X] = \mu$
- θ : la variance de X , $V(X) = \sigma^2$
- θ : la proportion de telle modalité, lorsque X est qualitative...

Notion d'estimation

X une variable aléatoire

θ un paramètre caractérisant X dans une population donnée.

Ex :

- θ : la moyenne de X , $E[X] = \mu$
- θ : la variance de X , $V(X) = \sigma^2$
- θ : la proportion de telle modalité, lorsque X est qualitative...

Généralement, θ n'est **pas connu** car on ne dispose pas de mesure de X sur toute la population

⇒ on va chercher à **estimer** θ à partir d'un échantillon X_1, \dots, X_n

- ⇒ estimation **ponctuelle** : donner une valeur approchée de θ
- ⇒ estimation **par intervalle** : donner un intervalle encadrant la vraie valeur de θ avec une certaine probabilité

Notion d'estimateur

Estimateur

Une statistique T fonction de l'échantillon : $T(X_1, \dots, X_n)$
dont on appréciera les qualités suivantes :

- convergent : $T(X_1, \dots, X_n) \xrightarrow{n \rightarrow \infty} \theta$
- sans biais : $E[T - \theta] = 0$
- de variance $V(T) = E[(T - \theta)^2]$ minimale

Plan

Notions de probabilités

- Généralités

- Variables aléatoires discrètes et lois associées

- Variables aléatoires continues et lois associées

- Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

- Description d'une variable quantitative

- Description d'une variable qualitative

- Description conjointe de plusieurs variables

Estimation

- Estimation ponctuelle**

- Intervalles de confiance

Estimateur de l'espérance et de la variance

Estimateur de l'espérance

La statistique $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ est le meilleur estimateur de μ

- convergent : $\bar{X} \xrightarrow{n \rightarrow \infty} \mu$
- sans biais : $E[\bar{X}] = \mu$
- de variance $V(\bar{X}) = \frac{\sigma^2}{n}$ minimale

Estimateur de l'espérance et de la variance

Estimateur de l'espérance

La statistique $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ est le meilleur estimateur de μ

- convergent : $\bar{X} \xrightarrow{n \rightarrow \infty} \mu$
- sans biais : $E[\bar{X}] = \mu$
- de variance $V(\bar{X}) = \frac{\sigma^2}{n}$ minimale

Estimateur de la variance

La statistique $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ est le meilleur estimateur de σ^2

- convergent : $S^2 \xrightarrow{n \rightarrow \infty} \sigma^2$
- sans biais : $E[S^2] = \sigma^2$
- de variance minimale

Rq : V^2 vu précédemment est biaisé $E[V^2] = \frac{n-1}{n} \sigma^2$

Estimateur d'une proportion

On s'intéresse à la proportion p d'individus ayant une certaine caractéristique dans une population.

Estimateur d'une proportion

$$F = \bar{X} = \frac{\sum_{i=1}^n X_i}{n},$$

où X_i est une v.a. de Bernoulli de paramètre p , définie par :

$$X_i = \begin{cases} 1 & \text{si l'individu } i \text{ possède la caractère } C \\ 0 & \text{sinon.} \end{cases}$$

Plan

Notions de probabilités

- Généralités

- Variables aléatoires discrètes et lois associées

- Variables aléatoires continues et lois associées

- Liaison entre deux variables aléatoires quantitatives

Statistiques descriptives

- Description d'une variable quantitative

- Description d'une variable qualitative

- Description conjointe de plusieurs variables

Estimation

- Estimation ponctuelle


- Intervalles de confiance**

Intervalle de confiance sur l'espérance

Loi de \bar{X}

- $X_i \sim \mathcal{N}(\mu, \sigma^2) \Rightarrow \bar{X} \sim \mathcal{N}(\mu, \frac{\sigma^2}{n})$
- lorsque les X_i ne sont pas gaussiens
Théorème centrale limite : $\bar{X} \xrightarrow{n \rightarrow \infty} \mathcal{N}(\mu, \frac{\sigma^2}{n})$

Intervalle de confiance sur μ




Intervalle de confiance sur la variance

Loi de \bar{X}

- $X_i \sim \mathcal{N}(\mu, \sigma^2) \Rightarrow \frac{n-1}{\sigma^2} S^2 \sim \chi_{n-1}^2$

Intervalle de confiance sur σ^2



Intervalle de confiance sur une proportion

Loi de F

- $F = \frac{\sum_{i=1}^n X_i}{n}$ avec $X_i \sim \mathcal{B}(p) \Rightarrow nF = \sum_{i=1}^n X_i \sim \mathcal{B}(n, p)$
- si n est suffisamment grand ($np > 5$ et $n(1-p) > 5$):

$$F \sim \mathcal{N}\left(p, \frac{p(1-p)}{n}\right)$$

Intervalle de confiance sur p

$$IC_{1-\alpha}(p)$$

$np > 5$ et $n(1-p) > 5$

$$\left[f + u_{\frac{\alpha}{2}} \sqrt{\frac{f(1-f)}{n}}, f - u_{\frac{\alpha}{2}} \sqrt{\frac{f(1-f)}{n}} \right]$$